

Statistinis Apvalinimas ir Nauji Skaičių Formatai Superkompiuteriuose

Mantas Mikaitis
Matematikos Departamentas
Mančesterio Universitetas

mantas.mikaitis@manchester.ac.uk

10-asis Lietuvos Jaunųjų Matematikų Susitikimas

**Gruodžio 28 d. 2021, Matematikos ir Informatikos Fakultetas,
Vilniaus Universitetas, Vilnius, Lietuva**

Kas yra Kompiuterių Aritmetika?

- **Skaičių vaizdavimas kompiuteryje**: turime registrus kurie laiko bitus (0/1)—kaip pavaizduoti realius skaičius?
- **Operacijos su skaičiais**: $+$, $-$, \times , \div , $\sqrt{}$ ir kt.
- **Specialios funkcijos**: e^x , $\log_e x$, \sin , \cos ir kt.
- **Apvalinimas**: link artimiausio skaičiaus, link nulio, link begalybes ir kt.

Bendrai

Dalies **realių skaičių** vaizdavimas ir skaičiavimas su jais.

Kompiuterių Aritmetikos Tyrimai

Tyrimai šitoje srityje gali buti: **programinė ir techninė įranga, bendri algoritmai aritmetikai, matematinė analizė**, paklaidų nagrinėjimas programose ir kt.

Slankiojo kablelio aritmetika

Ribota sistema $F = F(\beta, t, e_{min}, e_{max}) \in \mathbb{R}$ kurioje kiekvienas elementas turi išraišką

$$x = \pm m \times \beta^{e-p+1}.$$

Kompiuteriuose dažniausiai sutinkam $\beta = 2$.

p nusako **formato tikslumą**, $e_{min} \leq e \leq e_{max}$ yra **skaicius eilė**, o $m \leq \beta^p - 1$ yra **mantise** (p , e , ir m sveikieji skaičiai).

Pavyzdys

Apačioje—teigiami skaičiai sistemoje

$$F(\beta = 2, p = 3, e_{min} = -2, e_{max} = 3).$$



IEEE 754 Standartinė Aritmetika

- Standartas skirtas **suvienodinti aritmetikas tarp kompiuterių** (IEEE (2019)).
- Išleistas 1985, atnaujintas 2008 and 2019.
- Rekomenduojami **formatai, operacijos, apvalinimo metodai** ir kt.
- Dauguma šiodieninių kompiuterių palaiko.

Table: Formatai ($\beta = 2$) iš IEEE 754 standarto. f_{\min} —mažiausias normalizuotas skaičius, s_{\min} —mažiausias nenormalizuotas skaičius, f_{\max} —didžiausias skaičius.

	binary16	binary32	binary64
p	11	24	53
f_{\min}	2^{-14}	2^{-126}	2^{-1022}
s_{\min}	2^{-24}	2^{-149}	2^{-1074}
f_{\max}	$2^{15}(2 - 2^{-10})$	$2^{127}(2 - 2^{-23})$	$2^{1023}(2 - 2^{-52})$

IEEE 754 Standartinė Aritmetika

Kompiuterių atmintyje IEEE formatai laikomi naudojant bitus
(binarinė sistema):



Taip pat naujas **nestandatinis bfloat16 formatas**,
naudojamas neuroniniuose tinkluose:



TOP500 Superkompiuteriai ir jų Aritmetika

- **TOP500** (<https://www.top500.org/>) superkompiuterių (HPC) sarašas atnaujinamas kas pusę metų.
- **143 kompiuteriai turi NVIDIA vaizdo plokštės** (nuo 2016 našumo dalis išaugo nuo 12% iki 39%).
- Prieš dešimtmetį **binary16** nebuvo galima rasti, dabar vis daugėja.



Figure: NVIDIA vaizdo plokštė.



Figure: Top 2 Summit kompiuteris.




Figure: Top 1 Fugaku kompiuterio blokas.


TOP500 Superkompiuteriai ir jų Aritmetika

- Taip pat **naujo tipo operacijos su matricomis**:
“**tensor core**” (TC).
- Priima argumentus **binary16** matricas ir jas padaugina.
- Gražina matricas **binary32**.
- Žymiai greičiau negu dauginti atskirai po elementą.


Turint binary16 matricas $A \in R^{4 \times 4}$ ir $B \in R^{4 \times 4}$, binary32 matricą $C \in R^{4 \times 4}$, TC skaičiuoja $D = AB + C$ (**64 sudėties-daugybos operacijos vienu metu**).



TOP500 Superkompiuteriai ir jų Aritmetika



Aritmetikos Testavimas



binary32

$$d_{11} = \underbrace{a_{11}b_{11} + a_{12}b_{21} + a_{13}b_{31} + a_{14}b_{41}}_{\text{binary16}} + c_{11} \underbrace{\phantom{a_{11}b_{11} + a_{12}b_{21} + a_{13}b_{31} + a_{14}b_{41}}}_{\text{binary32}}$$

Exact mult. (not rounded to binary16):

22 signif. bits, 6 exp. bits, 1 sign bit


binary32 5-operand adder

Aritmetikos Testavimas


Pagrindinis klausimas: ar štie prietaisai matricoms dauginti užtikrintai veikia taip pat kaip programinė įranga (**pagal IEEE 754**)?

Pavyzdžiu, galim patikrinti:

- Kokia seka **keturios sudėties operacijos** yra atliekamos?
- Kaip apvalinama sudėtyje?
- Daugiau: [Fasi, Higham, Mikaitis, Pranesh \(2021\)](#)




Aritmetikos Testavimas



Paklaidos Matricų Daugyboje

$$a_{i,j}, b_{i,j} \in (-0.5, 0.5]$$

$$a_{i,j}, b_{i,j} \in (0, 1]$$



Rezultatai: Fasi, Higham, Lopez, Mary, Mikaitis (2022).


Statistinis Apvalinimas

Apibrėžimas iš Connolly, Higham, Mary (2021).

Jeigu $x \in \mathbb{R}$, $\lfloor x \rfloor \leq x \leq \lceil x \rceil$ (x tarp dvieju slankiojo kablelio skaičių), **statistinis apvalinimas** apibrėžiamas kaip

$$\text{SR}(x) = \begin{cases} \lceil x \rceil \text{ su tikimybe } q(x), \\ \lfloor x \rfloor \text{ su tikimybe } 1 - q(x), \end{cases} \quad (1)$$

ir $q(x) = \frac{x - \lfloor x \rfloor}{\lceil x \rceil - \lfloor x \rfloor}$.



Statistinis Apvalinimas

- SR **nėra dažnai sutinkamas kompiuteriuose** (nors yra tarp Intel ir Graphcore tam tikrų mikroprocesorių).
- Minėtas publikacijoje iš 1950, bet tik neseniai vėl susidomėta neuroninių tinklų literatūroje.
- **Statistiškai naudingas apvalinimo metodas:** neapvalina į vieną pusę net jeigu visi skaičiai arčiau kairiojo slankiojo kablelio skaičiaus.

Tyrimai ties Statistiniu Apvalinimu

Aritmetikos su SR teorija, **paklaidos** mokslinėse simuliacijose, **SR algoritmai** programinei ir techninei įrangai su SR mikroprocesoriouse.

Euler Metodas su Statistiniu Apvalinimu

Spredžiam dvi diferencialines lygtis su Euler metodu:

- $y_{n+1} = y_n - hy_n$, su $y_0 = 2^{-6}$, intervale $[0, 1]$ su žingsniais $h = 1/n$.
- $y_{n+1} = y_n - h\frac{y_n}{20}$, su $y_0 = 1$, intervale $[0, 2^{-6}]$ su žingsniais $h = 2^{-6}/n$.

Eksperimentas keičiant n

Didinsim $n \in [10, 10^6]$ tol kol metodo žingsnis pasidarys mažesnis už tarpus tarp skaičių slankiojo kablelio aritmetikoje, kur ir pasimatys apvalinimo aritmetikoje poveikis paklaidoms.


Daugiau info: [Croci, Fasi, Higham, Mary, Mikaitis \(2021\)](#), [Fasi, Mikaitis \(2021\)](#).

Euler Metodas su Statistiniu Apvalinimu

Rezultatai: Fasi, Mikaitis (2021).

(a) $y' = -y$, $y(0) = 2^{-6}$, over $[0, 1]$.

(b) $y' = -\frac{y}{20}$, $y(0) = 1$ over $[0, 2^{-6}]$.



Euler Metodas su Statistiniu Apvalinimu

Kitas pavyzdys. Spredžiam

$$u'(t) = v(t), \quad v'(t) = -u(t)$$

kai $u(0) = 1$, $v(0) = 0$ (**vienetinis skritulys** uv koordinačių plokštėje).

Sprendimas naudojant Euler metodą (žingsniai $h = 2\pi/n$):


$$u_{k+1} = u_k + hv_k, \quad v_{k+1} = v_k - hu_k.$$

Eksperimentas mažinant h

Didinam n kol apvalinimo paklaidos dominuoja.

Daugiau info: [Croci, Fasi, Higham, Mary, Mikaitis \(2021\)](#),
[Fasi, Mikaitis \(2021\)](#).

Euler Metodas su Statistiniu Apvalinimu



Ivairių Aritmetikų Simuliacija ant Kasdieninių Kompiuterių

- Jeigu neturim priegos prie naujų aritmetikų, ka darom?
- **Simuliujam aritmetikas** ant stalinių kompiuterių.
- Ant MATLAB galim naudoti funkciją `chop` ([Higham, Pranesh \(2019\)](#)).
- Tarp C kalbos yra `CPFloat` funkcija ([Fasi, Mikaitis \(2020\)](#))—veikia ir tarp MATLAB.
- Palaiko betkokią aritmetiką $p \leq 32$.
- Palaiko visus apvalinimo metodus, įskaitant statistinj.
- **Naudoja binary64 ant procesoriaus operacijoms** ir tada nunuliuoja kiek reikia bitų dešnėje.

binary64		11		52 bits	
----------	--	----	--	---------	--

MATLAB CPFfloat pavyzdys

```
>> options.format = 'binary16';
>> x = pi;
>> x
x = 3.14159265358979

>> xr = cpffloat(x, options);
>> xr
xr = 3.140625

>> x*x
ans = 9.86960440108936

>> cpffloat(x*x, options)
ans = 9.8671875
```

- Vis dažniau atsiranda **binary16**, **bfloat16** ir matricų operacijos kompiuterių mikroprocesoriuose.
- Programinė įranga adaptuojama **dėl geresnio našumo**.
- Pristačiau progresą testuojant ir simuliujant įvairias aritmetikas.
- Skaidrės
[https://mmikaitis.github.io/talks/.](https://mmikaitis.github.io/talks/)

Visada ieškau su kuo bendradarbiauti tyrimuose šioje srityje. Susiekimui mantas.mikaitis@manchester.ac.uk.

References I



IEEE

IEEE Standard for Floating-Point Arithmetic, IEEE Std 754-2019 (revision of IEEE Std 754-2008).
Institute of Electrical and Electronics Engineers,
Piscataway, NJ, USA. 2019.



M. Fasi, N. J. Higham, M. Mikaitis, and S. Pranesh.
Numerical Behavior of NVIDIA Tensor Cores.
PeerJ Comput. Sci. 7:e330 (2021).



M. Fasi, N. J. Higham, F. Lopez, T. Mary, and
M. Mikaitis.
Multiword Matrix Multiplication: General Error Analysis
and Application to GPU Tensor Cores.
2022. In preparation.

References II

-  M. P. Connolly, N. J. Higham, and T. Mary.
Stochastic Rounding and Its Probabilistic Backward Error Analysis.
SIAM J. Sci. Comput. 43, A566–A585. 2021.
-  M. Croci, M. Fasi, N. J. Higham, T. Mary, and M. Mikaitis.
Stochastic Rounding: Implementation, Error Analysis, and Applications.
MIMS EPrint 2021.17. 2021.
-  N. J. Higham and S. Pranesh.
Simulating Low Precision Floating-Point Arithmetic.
SIAM J. Sci. Comput. 41, C585–C602. 2019.

References III



M. Fasi and M. Mikaitis.

CPFloat: A C Library for Emulating Low-Precision Arithmetic.

MIMS EPrint 2020.22. 2020.



M. Fasi and M. Mikaitis.

Algorithms for Stochastically Rounded Elementary Arithmetic Operations in IEEE 754 Floating-Point Arithmetic.

IEEE Trans. Emerg. Topics Comput. 9, 1451–1466. 2021.